

Aprendizaje automático para la detección de plásticos marinos: análisis bibliométrico de la producción científica

*Machine learning for marine plastic detection: a bibliometric analysis of scientific
production*

Fernando Antonio Sernaque Aucchuasi ^a 
✉ fsernaque@unfv.edu.pe

Samuel Carlos Reyna Mandujano ^a 

Saúl Yonathan López Huamán ^a 

Max Alejandro Huaranja Montaña ^a 

^a Conservación Ecológica, Socioambiental y Divulgación Científica-CECOSAM. Universidad Nacional
Federico Villarreal. Lima, Perú

Resumen

Palabras clave:

Aprendizaje automático;
Contaminación por plásticos
marinos; Detección de
plásticos; Análisis
bibliométrico; Teledetección

Keywords:

Machine Learning; Marine
plastic pollution; Plastic
detection; Bibliometric
analysis; Remote sensing

Cómo citar: Sernaque
Aucchuasi FA, Reyna
Mandujano SC, López
Huamán SY, Huaranja
Montaña MA. Aprendizaje
automático para la
detección de plásticos
marinos: análisis
bibliométrico de la
producción científica. ALFA
Revista de Investigación en
Ciencias Agronómicas y
Veterinarias.
2026;10(29):01-19
<https://doi.org/10.33996/revistaalfa.v10i29.483>



Contexto: La contaminación por plásticos marinos es un problema ambiental creciente que afecta ecosistemas costeros y oceánicos. El aprendizaje automático ha emergido como una herramienta clave para mejorar la detección, clasificación y monitoreo de estos residuos mediante el uso de imágenes satelitales, aéreas y submarinas. **Objetivo:** Analizar la evolución, estructura científica y tendencias de la investigación sobre aprendizaje automático aplicado a la detección de plásticos marinos. **Metodología:** Se realizó un estudio bibliométrico de artículos indexados en Scopus publicados entre 2000 y 2025. Los registros fueron seleccionados mediante un proceso sistemático basado en PRISMA y analizados con Bibliometrix en RStudio. Se evaluaron tendencias de publicación, revistas, autores, instituciones, citas, distribución geográfica, redes de colaboración y estructura temática. **Resultados:** Se evidenció un crecimiento sostenido de publicaciones desde 2020, con predominio de enfoques basados en aprendizaje profundo, visión por computadora, sensores remotos y detección automatizada. La producción científica se concentra en revistas de ciencias ambientales, contaminación marina y teledetección, con mayor aporte de Asia y Europa. Las redes de colaboración internacional muestran una estructura fragmentada. **Conclusiones:** La investigación en aprendizaje automático aplicado a plásticos marinos ha evolucionado hacia enfoques altamente especializados. Sin embargo, persisten brechas en la estandarización de datos, la comparabilidad de modelos y la cooperación interregional, lo que limita la consolidación de avances globales en el área.

Abstract

Context: Marine plastic pollution is an escalating environmental problem affecting coastal and oceanic ecosystems. Machine Learning has emerged as a pivotal tool for improving the detection, classification, and monitoring of these residues through the use of satellite, aerial, and underwater imagery. **Objective:** This study aims to analyze the evolution, scientific structure, and research trends of Machine Learning applied to marine plastic detection. **Methodology:** A bibliometric study of Scopus-indexed articles published between 2000 and 2025 was conducted. Records were selected through a systematic process based on PRISMA guidelines and analyzed with Bibliometrix in RStudio. Publication trends, journals, authors, institutions, citations, geographic distribution, collaboration networks, and thematic structure were evaluated. **Results:** A sustained growth in publications has been evidenced since 2020, with a predominance of approaches based on Deep Learning, computer vision, remote sensing, and automated detection. Scientific production is

concentrated in journals of environmental sciences, marine pollution, and remote sensing, with the largest contributions from Asia and Europe. International collaboration networks show a fragmented structure. **Conclusions:** Research in Machine Learning applied to marine plastics has evolved toward highly specialized approaches. However, gaps remain in data standardization, model comparability, and interregional cooperation, limiting the consolidation of global advances in the area.

Introducción

Cada año se producen cientos de millones de toneladas de plásticos a nivel global, con una producción anual que alcanzó aproximadamente 360 millones de toneladas en 2018 y que continúa en aumento ⁽¹⁾. Una fracción significativa de estos materiales termina en los océanos como resultado de deficiencias en la gestión de residuos, descargas terrestres, transporte fluvial y procesos de acumulación en zonas costeras. Se estima que entre 19 y 23 millones de toneladas métricas de residuos plásticos ingresaron a los ecosistemas acuáticos en 2016, lo que representó alrededor del 11 % de la producción global de ese año ⁽²⁾. Bajo los escenarios actuales de gestión, las emisiones anuales de plástico hacia ambientes acuáticos podrían incrementarse hasta 53 millones de toneladas para 2030, superando ampliamente la capacidad de mitigación existente ^(2,3).

La persistencia de estos residuos en el medio marino se explica por las propiedades físico-químicas de los polímeros, que favorecen su acumulación en zonas costeras, mar abierto y aguas profundas, incluso en regiones remotas como el Ártico ⁽¹⁾. Esta acumulación sostenida genera impactos severos sobre la biodiversidad marina, afectando a aves, tortugas, peces y mamíferos marinos mediante ingestión, enredo y alteración de hábitats, con consecuencias ecológicas ampliamente documentadas ^(1,2). Además, los residuos plásticos marinos comprenden materiales de distinto tamaño y origen, desde macroplásticos visibles hasta microplásticos derivados de la fragmentación progresiva de objetos mayores o liberados directamente al ambiente como partículas de pequeño tamaño. Esta diferenciación es relevante porque las estrategias de detección, los sensores utilizados y los modelos computacionales aplicados varían según la escala del residuo, el entorno de observación y el tipo de dato disponible.

Asimismo, la fragmentación progresiva de los residuos plásticos da lugar a microplásticos, los cuales han sido detectados de forma generalizada en agua potable, sal marina y organismos acuáticos, facilitando su incorporación y transferencia a lo largo de las cadenas tróficas marinas ^(1,3). Estos procesos refuerzan la necesidad de sistemas de monitoreo capaces de detectar, cuantificar y caracterizar residuos plásticos a diferentes escalas espaciales y temporales, particularmente en entornos marinos de alta complejidad. El monitoreo tradicional basado en observación directa, muestreo manual o inspecciones localizadas ofrece información valiosa, pero presenta limitaciones operativas cuando se requiere cubrir áreas extensas, condiciones ambientales cambiantes o registros repetidos en el tiempo. Por ello, el uso de imágenes satelitales, vehículos aéreos no tripulados, cámaras submarinas, sensores multiespectrales y datos ambientales georreferenciados ha adquirido importancia en los sistemas contemporáneos de vigilancia ambiental.

La contaminación plástica marina se encuentra vinculada con el Objetivo de Desarrollo Sostenible 14, orientado a la conservación y uso sostenible de los océanos y sus recursos. En este sentido, la persistencia y dispersión de los residuos plásticos comprometen la resiliencia de los ecosistemas marinos y dificultan el cumplimiento de las metas asociadas a este objetivo ^(4,5). En este marco, el logro del ODS 14 depende en gran medida de la disponibilidad de información confiable y de sistemas de monitoreo capaces de detectar, cuantificar y caracterizar la presencia de residuos plásticos en entornos marinos a diferentes escalas espaciales y temporales.

En los últimos años, el aprendizaje automático o machine learning se ha posicionado como una herramienta relevante para el monitoreo ambiental, al permitir el análisis eficiente de grandes volúmenes de datos y apoyar la toma de decisiones en contextos complejos y dinámicos ^(6,7). El aprendizaje automático comprende un conjunto de métodos computacionales que permiten identificar patrones, clasificar objetos, estimar resultados o reconocer estructuras en los datos a partir de algoritmos entrenados con información previa. En el caso del monitoreo de plásticos marinos, estas técnicas pueden aplicarse a tareas supervisadas de detección y clasificación, así como a procedimientos de segmentación de imágenes orientados a delimitar la presencia de residuos en escenas satelitales, aéreas o submarinas.

En ambientes marinos, estas técnicas han sido aplicadas de forma creciente al análisis de datos procedentes de sensores in situ, imágenes aéreas y satelitales, con la finalidad de automatizar tareas de detección, clasificación y monitoreo de contaminantes. Diversos estudios han demostrado la capacidad del aprendizaje automático para identificar residuos plásticos y analizar la distribución de microplásticos con altos niveles de precisión, posicionándolo como un componente metodológico central en los sistemas contemporáneos de monitoreo de la contaminación marina ⁽⁸⁻¹⁰⁾.

Dentro del conjunto de técnicas que conforman el aprendizaje automático, los enfoques basados en aprendizaje profundo o deep learning representan una evolución metodológica caracterizada por el uso de arquitecturas neuronales profundas capaces de aprender patrones complejos a partir de grandes volúmenes de datos. Estas arquitecturas incluyen redes neuronales convolucionales, modelos de detección de objetos y enfoques de segmentación semántica que han sido utilizados para reconocer residuos plásticos en imágenes con diferentes resoluciones, condiciones de iluminación, fondos marinos heterogéneos y variabilidad espacial. En los últimos años, estos enfoques han adquirido relevancia en la detección y clasificación de plásticos marinos, impulsados principalmente por el análisis automatizado de imágenes aéreas, satelitales y submarinas. Diferentes estudios han demostrado que el empleo de redes neuronales profundas permite mejorar la precisión y el grado de automatización en los procesos de detección de residuos plásticos, consolidando su uso en aplicaciones de monitoreo ambiental ⁽¹¹⁻¹⁵⁾.

A pesar del crecimiento sostenido de la investigación sobre el uso de aprendizaje automático en la detección de plásticos marinos, la literatura existente presenta una alta fragmentación temática y metodológica. Predominan estudios centrados en aplicaciones específicas, con escasa integración que permita comprender de manera global la evolución del campo, la emergencia de enfoques dominantes o la configuración de comunidades científicas y redes de colaboración ⁽¹⁶⁻¹⁸⁾. Esta fragmentación se expresa en la diversidad de objetos de estudio, plataformas de captura, tipos de sensores, algoritmos utilizados, métricas de evaluación y contextos ambientales analizados.

En consecuencia, resulta difícil establecer con claridad cuáles son las principales líneas de desarrollo, qué revistas e instituciones concentran la producción, qué documentos han tenido mayor influencia y cómo se organizan las tendencias temáticas del campo. Además, la dispersión de la producción científica entre múltiples disciplinas y fuentes editoriales dificulta la identificación de tendencias consistentes y frentes de investigación emergentes.

En este contexto, el análisis bibliométrico constituye una herramienta adecuada para mapear de manera sistemática la estructura intelectual de un campo de investigación, analizar su evolución temporal e identificar actores clave, redes de colaboración y áreas temáticas en desarrollo. En el ámbito ambiental, este enfoque ha demostrado utilidad para analizar la adopción de técnicas de aprendizaje automático y visualizar dinámicas de producción científica y colaboración interdisciplinaria ^(16,19-21).

Por ello, el objetivo de este estudio fue caracterizar la estructura intelectual, la evolución temporal reciente y la dinámica colaborativa de la investigación que aplica técnicas de aprendizaje automático a la detección y el monitoreo de plásticos marinos, mediante un análisis bibliométrico basado en la base de datos Scopus.

Este enfoque busca ofrecer una visión ordenada y reproducible del desarrollo del campo, así como identificar tendencias emergentes, núcleos temáticos y brechas persistentes relacionadas con la estandarización de datos, la comparabilidad metodológica y la cooperación científica internacional en el monitoreo ambiental marino.

Métodos

En este estudio se aplicó un enfoque bibliométrico para analizar la literatura científica sobre el uso del aprendizaje automático en la detección de plásticos marinos. La investigación se orientó a examinar la evolución temporal de la producción científica, los patrones de citación, la productividad de autores e instituciones, la distribución geográfica, las redes de colaboración y la estructura temática del campo. Este enfoque permitió caracterizar la configuración intelectual y temática de la investigación, sin asumir que el análisis bibliométrico sustituye una evaluación técnica individual del desempeño de cada modelo o algoritmo reportado en los estudios primarios. El procedimiento siguió criterios metodológicos utilizados en estudios bibliométricos previos (22,23).

Fuente de datos y estrategia de búsqueda

La búsqueda bibliográfica se diseñó a partir de una lógica conceptual integradora que combinó tres dimensiones complementarias: (i) la problemática ambiental asociada a la contaminación por plásticos en entornos marinos y costeros; (ii) la aplicación de técnicas de aprendizaje automático y aprendizaje profundo; y (iii) su uso en tareas operativas de detección, clasificación y segmentación de plásticos marinos. Esta combinación permitió delimitar el corpus hacia estudios con aplicación metodológica directa, evitando incluir trabajos puramente conceptuales, revisiones generales o investigaciones no centradas en tareas automatizadas de identificación o monitoreo de residuos plásticos.

La búsqueda se realizó exclusivamente en la base de datos Scopus, seleccionada por su cobertura interdisciplinaria en ciencias ambientales, oceanografía, ingeniería, teledetección y ciencias de la computación, así como por la estandarización de sus metadatos, condición relevante para el análisis bibliométrico reproducible (22). La ecuación de búsqueda abarcó el periodo comprendido entre 2000 y diciembre de 2025, con el propósito de recuperar los registros potencialmente pertinentes para el campo de estudio.

Las consultas se ejecutaron en los campos de título, resumen y palabras clave (TITLE-ABS-KEY). La estrategia combinó términos relacionados con plásticos marinos, técnicas de aprendizaje automático y profundo, verbos asociados a tareas operativas y descriptores del entorno marino o costero. La ecuación de búsqueda utilizada fue la siguiente:

TITLE-ABS-KEY (("marine plastic*" OR "marine debris" OR "marine litter" OR "floating plastic*" OR "plastic debris" OR "plastic litter" OR microplastic* OR macroplastic*) AND ("machine learning" OR "deep learning" OR "artificial intelligence" OR "computer vision" OR CNN OR "convolutional neural network*" OR YOLO OR "U-Net" OR UNet OR transformer* OR "vision transformer" OR ViT OR "support vector machine*" OR SVM OR "random forest") AND (detect* OR classify* OR segment*) AND (marine OR ocean* OR coastal OR "sea surface" OR underwater)) AND PUBYEAR > 1999 AND PUBYEAR < 2026 AND DOCTYPE (ar)

La búsqueda se ejecutó el 5 de enero de 2026. En esa fecha se recuperaron 205 registros iniciales, los cuales fueron exportados desde Scopus y sometidos posteriormente al proceso de depuración, cribado y análisis bibliométrico.

Selección de estudios y criterios de elegibilidad

La selección de los estudios se realizó mediante un procedimiento de identificación, cribado, elegibilidad e inclusión adaptado a las directrices PRISMA, con el fin de transparentar el flujo de selección documental. El uso de PRISMA en este estudio tuvo como finalidad ordenar y reportar de manera clara las decisiones de inclusión y exclusión aplicadas al corpus bibliométrico (23,24).

A partir de los 205 registros identificados en Scopus, se realizó un cribado inicial por título y resumen. En esta etapa se excluyeron 57 documentos por no cumplir los criterios temáticos o metodológicos definidos. Posteriormente, 148 documentos fueron evaluados en la fase de elegibilidad mediante revisión del contenido disponible. En esta segunda etapa se excluyeron 20 artículos adicionales por no aplicar aprendizaje automático o aprendizaje profundo como componente metodológico central, o por no estar directamente orientados a la detección, clasificación, segmentación o monitoreo de plásticos marinos.

Se incluyeron exclusivamente artículos originales de investigación que abordaran la contaminación por plásticos en entornos marinos o costeros y que utilizaran técnicas de aprendizaje automático o aprendizaje profundo en tareas operativas de detección, identificación, clasificación, segmentación o monitoreo. Se excluyeron artículos de revisión, actas de congresos, documentos editoriales, trabajos conceptuales y estudios no pertinentes al objetivo del análisis. Como resultado del proceso de selección, 128 artículos fueron incluidos en el análisis bibliométrico final. El flujo completo del proceso se presenta en la Figura 1.




Figura 1. Diagrama de selección de documentos adaptado a PRISMA

Procedimientos de análisis bibliométrico

El procesamiento y análisis de los datos se realizó en un entorno reproducible utilizando el paquete Bibliometrix en RStudio (25). La depuración inicial de metadatos se apoyó en hojas de cálculo para verificar consistencia en nombres de autores, fuentes, afiliaciones, países, palabras clave y registros bibliográficos. El corpus final se analizó mediante un enfoque de mapeo científico que integró indicadores bibliométricos

descriptivos y técnicas de análisis de redes, con el fin de examinar la estructura temática, conceptual y colaborativa del campo (22,23).

Se calcularon indicadores de producción científica anual, revistas más productivas, autores e instituciones con mayor producción, documentos con mayor impacto de citación, distribución geográfica de la producción, redes de colaboración y frecuencia de palabras clave. Estos indicadores fueron seleccionados porque permiten describir la evolución del campo, identificar actores científicos relevantes y reconocer la organización temática de la investigación sobre aprendizaje automático aplicado a la detección de plásticos marinos.

El análisis temático se desarrolló mediante redes de coocurrencia de palabras clave para identificar clústeres conceptuales y relaciones entre enfoques metodológicos y aplicaciones. Antes de construir las redes, se realizó una normalización básica de términos para reducir variaciones ortográficas, duplicidades semánticas y diferencias entre expresiones equivalentes. Este procedimiento permitió agrupar términos relacionados y mejorar la interpretación de los resultados bibliométricos.

Para mejorar la estabilidad estructural y la legibilidad de las redes, se realizó un filtrado progresivo de términos previamente normalizados, priorizando aquellos con mayor frecuencia y relevancia estructural. Esta decisión buscó reducir nodos periféricos débilmente conectados que podían introducir ruido visual y dificultar la interpretación de los clústeres temáticos. Las redes resultantes fueron interpretadas considerando la frecuencia de aparición de los términos, sus conexiones y su posición relativa dentro de la estructura temática del campo.

Resultados

Evolución anual de la producción científica

La Figura 2 presenta la evolución anual de la producción científica sobre aplicaciones de aprendizaje automático para la detección de plásticos marinos entre 2018 y 2025. La producción fue limitada en 2018 y 2019, con dos y una publicación, respectivamente; sin embargo, a partir de 2020 se observa un incremento sostenido en el número de artículos publicados. La producción pasó de 7 publicaciones en 2020 a 14 en 2021 y 22 en 2022. Aunque en 2023 se registró una disminución relativa, con 18 publicaciones, la producción volvió a incrementarse en 2024, con 25 artículos, y alcanzó su valor más alto en 2025, con 39 publicaciones. En definitiva, los datos muestran una tendencia ascendente durante la etapa más reciente del periodo analizado, lo que evidencia una mayor atención científica hacia el uso de métodos automatizados para la detección y monitoreo de plásticos marinos.




Figura 2. Producción científica anual.

Revistas líderes y fuentes de publicación

La Tabla 1, presenta las revistas con mayor productividad científica en el campo de las aplicaciones del aprendizaje automático para la detección y monitoreo de plásticos marinos. La distribución de publicaciones muestra una concentración moderada en revistas de alto impacto, predominantemente clasificadas en el cuartil Q1 y orientadas principalmente a ciencias ambientales, oceanografía y teledetección. Marine Pollution Bulletin registra el mayor número de documentos (n = 17), seguida de Remote Sensing (n = 8) y Science of the Total Environment (n = 7). La presencia de revistas con orientación técnica, incluidas publicaciones del IEEE, indica que las contribuciones en este campo también se difunden en revistas vinculadas con ingeniería, observación terrestre y tecnología aplicada.

Tabla 1. Revistas más productivas.

Revista	Artículos	País	Cuartil (2024)	SJR (2024)	Categorías temáticas principales
Marine Pollution Bulletin	17	Reino Unido	Q1	1.402	Ciencias acuáticas; Contaminación
Remote Sensing	8	Suiza	Q1	1.019	Ciencias de la Tierra y planetarias
Science of the Total Environment	7	Países Bajos	Q1	2.137	Ciencias ambientales; Contaminación
IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing	4	Estados Unidos	Q1	1.349	Observación de la Tierra; Teledetección
Journal of Marine Science and Engineering	4	Suiza	Q2	0.579	Ingeniería oceánica; Ciencias marinas
Korean Journal of Remote Sensing	4	República de Corea	Q3	0.293	Teledetección; Ciencias de la Tierra
Environmental Pollution	3	Reino Unido	Q1	2.205	Contaminación; Salud ambiental
IEEE Journal of Oceanic Engineering	3	Estados Unidos	Q1	1.003	Ingeniería oceánica; Ingeniería eléctrica
Scientific Reports	3	Reino Unido	Q1	0.874	Ciencias multidisciplinarias
Applied Sciences	2	Suiza	Q2	0.521	Ingeniería; Aplicaciones de ciencias de la computación

Nota. Las categorías temáticas corresponden a las áreas principales de cada revista según la clasificación de Scimago Journal Rank (SJR). No se muestran categorías secundarias.

Autores más productivos y afiliaciones institucionales

La Tabla 2, presenta los autores con mayor productividad científica y sus respectivas afiliaciones institucionales en el campo del aprendizaje automático aplicado a la detección de plásticos marinos. La producción se concentra en un grupo reducido de investigadores, con un máximo de cuatro publicaciones por autor. Varias instituciones aparecen representadas más de una vez, incluidas universidades y centros de investigación ubicados en Portugal, República de Corea, China, Bélgica y Arabia Saudita. Los datos muestran que los autores más productivos se encuentran afiliados principalmente a instituciones vinculadas con ingeniería, ciencias marinas e investigación científica aplicada.

Tabla 2. Autores más productivos y afiliaciones institucionales.

Autor	Artículos	Institución	País
Andriolo, U.	4	Institute for Systems Engineering and Computers	Portugal
Bak, S.	4	Research Institute, IREMTECH	República de Corea
Chen, Y.	4	Zhejiang Ocean University	China
Gonçalves, G.	4	University of Coimbra	Portugal
Jang, S.	4	Research Institute, IREMTECH	República de Corea
Zhang, X.	4	King Abdullah University of Science and Technology	Arabia Saudita
Da Silva, E.	3	INESC TEC	Portugal
De Witte, B.	3	Flanders Marine Institute	Bélgica
Everaert, G.	3	Flanders Marine Institute	Bélgica
Janssen, C.	3	Ghent University	Bélgica

Nota. Se muestran los autores con mayor número de artículos dentro del corpus analizado. Las instituciones corresponden a las afiliaciones registradas en los documentos indexados en Scopus.

Documentos con mayor impacto de citación

La Tabla 3, presenta los documentos más citados en el campo del aprendizaje automático aplicado a la detección de plásticos marinos, ordenados según el número total de citas. Los artículos con mayor impacto fueron publicados entre 2018 y 2022, principalmente en revistas orientadas a ciencias ambientales y contaminación, como Marine Pollution Bulletin, Science of the Total Environment y Environmental Pollution. El número total de citas y las citas por año ofrecen indicadores complementarios del impacto académico durante el periodo analizado. Asimismo, los valores de citación normalizada muestran variaciones entre los documentos, lo que sugiere diferencias en el rendimiento relativo de citación dentro del corpus evaluado.

Tabla 3. Documentos con mayor impacto de citación en el campo.

Documento	Año	Revista	Citas totales	Citas por año	Citas normalizadas
Martin, C., et al.	2018	Marine Pollution Bulletin	182	20.22	1.31
Fallati, L., et al.	2019	Science of the Total Environment	161	20.13	1
Meyers, N., et al.	2022	Science of the Total Environment	142	28.4	4.07
Gonçalves, G., et al.	2020	Science of the Total Environment	120	17.14	1.65
Wolf, M., et al.	2020	Environmental Research Letters	105	15	1.44
Vidal, C., & Pasquini, C.	2021	Environmental Pollution	104	17.33	1.88
Politikos, D., et al.	2021	Marine Pollution Bulletin	97	16.17	1.75
Acuña-Ruz, et al.	2018	Remote Sensing of Environment	95	10.56	0.69
Kikaki, K., et al.	2022	PLOS ONE	93	18.6	2.67
García-Garín, O., et al.	2021	Environmental Pollution	92	15.33	1.66

Nota. Las citas totales corresponden al número acumulado de citas registradas para cada documento durante el periodo analizado. Las citas por año permiten comparar la visibilidad anual de los artículos, mientras que las citas normalizadas indican el rendimiento relativo de citación considerando diferencias temporales entre publicaciones.

Distribución geográfica de la producción científica

La Figura 3, presenta la distribución geográfica de la producción científica según las afiliaciones de país de los autores en estudios sobre aprendizaje automático aplicado a la detección de plásticos marinos. China registra el mayor número de afiliaciones de autor ($n = 72$), seguida por la República de Corea ($n = 49$) e India ($n = 37$). También destacan varios países europeos, entre ellos Portugal ($n = 21$), Grecia ($n = 20$), Italia ($n = 16$), España ($n = 13$) y Bélgica ($n = 12$). Estados Unidos registra 15 afiliaciones dentro del conjunto de datos analizado. Los hallazgos muestran que la distribución evidencia que la producción científica se concentra en un grupo relativamente reducido de países con mayor representación en el campo.




Figura 3. Distribución geográfica de la producción científica por país.

Análisis de palabras clave

La Figura 4, muestra la frecuencia de palabras clave extraídas de los títulos, resúmenes y palabras clave de autor de los documentos analizados. Los términos más frecuentes incluyen machine learning, marine debris, deep learning, microplastics, object detection y convolutional neural networks. La presencia destacada de estos términos evidencia una fuerte representación de enfoques computacionales y técnicas basadas en imágenes dentro del corpus analizado. Asimismo, términos como environmental monitoring, remote sensing y plastic waste reflejan la amplitud temática del campo, al vincular la detección automatizada de residuos plásticos con el monitoreo ambiental, la teledetección y la gestión de la contaminación marina.



Figura 4. Palabras clave más frecuentes.

Estructura temática del campo

La Figura 5, muestra la red de coocurrencia de palabras clave, en la cual se identifican dos clústeres temáticos principales e interconectados. El primer clúster incluye términos como machine learning, plastic waste y waste, los cuales aparecen con frecuencia dentro de la red y se relacionan con el componente computacional y metodológico del campo. El segundo clúster agrupa palabras clave como marine pollution, marine debris, deep learning y remote sensing, conformando un conjunto de nodos asociados con el contexto ambiental, la contaminación marina y las plataformas de observación. La presencia de vínculos entre ambos clústeres sugiere una interacción temática entre los enfoques computacionales y las investigaciones orientadas al monitoreo de la contaminación marina. En este sentido, la estructura de la red evidencia que el campo se articula alrededor de la aplicación de técnicas de aprendizaje automático y aprendizaje profundo a problemas de detección, clasificación y monitoreo de residuos plásticos en entornos marinos.




Figura 5. Red de coocurrencia de palabras clave del campo analizado.

Evolución temática del campo

La Figura 6, presenta la evolución temática de la investigación sobre aprendizaje automático aplicado a la detección de plásticos marinos en dos periodos: 2018–2021 y 2022–2025. En el primer periodo, el término *marine debris* aparece como uno de los ejes principales y se vincula con palabras clave como *machine learning*, *artificial neural network* y *aerial photograph*. Esta configuración sugiere una etapa inicial orientada al uso de enfoques computacionales y datos visuales para el reconocimiento de residuos marinos. En el segundo periodo, la estructura temática muestra un desplazamiento hacia términos asociados con *deep learning*, junto con referencias más diferenciadas a *plastic* y *microplastics*. Esta transición evidencia una reorganización del énfasis temático dentro del corpus analizado, con mayor presencia de enfoques basados en aprendizaje profundo y técnicas automatizadas de detección. La comparación entre ambos periodos indica

una evolución desde aproximaciones iniciales de identificación de residuos marinos hacia líneas más especializadas vinculadas con visión por computadora, clasificación y detección automatizada de plásticos.




Figura 6. Evolución temática del campo analizado.

Redes de colaboración científica

La Figura 7, presenta la red de coautoría en la investigación sobre aprendizaje automático aplicado a la detección de plásticos marinos. La red se organiza en múltiples clústeres pequeños, caracterizados por conexiones internas relativamente densas y vínculos limitados entre grupos. Varios autores aparecen agrupados en subredes estrechamente conectadas, mientras que las colaboraciones entre clústeres son menos frecuentes. Además, uno de los clústeres asociados con Bak y Jang presenta un mayor número relativo de autores interconectados. Asimismo, se observan diversas colaboraciones diádicas, lo que indica patrones de coautoría concentrados en equipos de investigación específicos. De modo que la estructura de la red sugiere una colaboración científica fragmentada, con grupos especializados que mantienen mayor interacción interna que conexiones amplias con otros equipos del campo.




Figura 7. Red de coautoría entre autores.

La Figura 8, presenta el mapa de colaboración internacional en la investigación sobre aprendizaje automático aplicado a la detección de plásticos marinos. La red muestra una concentración de vínculos de colaboración en un grupo limitado de países, principalmente China, Estados Unidos, Japón y varias naciones europeas, entre ellas Países Bajos, Francia, Reino Unido y Noruega. Por otra parte, Asia oriental y América del Norte

presentan conexiones más numerosas y visibles, mientras que los países europeos conforman múltiples vínculos de colaboración regional. En contraste, América Latina, África y algunas regiones de Medio Oriente muestran una menor presencia de conexiones internacionales, generalmente asociadas con países de mayor producción científica. Por tanto, la estructura de la red refleja una colaboración internacional concentrada en un número reducido de países, con menor conectividad comparativa en otras regiones representadas.




Figura 8. Red de colaboración internacional.

Discusión

El incremento sostenido de publicaciones desde 2020 indica que la aplicación del aprendizaje automático a la detección de contaminación plástica marina ha ganado mayor visibilidad dentro de la investigación ambiental y tecnológica. Más que demostrar por sí solo una consolidación metodológica completa, este crecimiento evidencia una expansión reciente del interés científico y una mayor incorporación de enfoques automatizados para el monitoreo de residuos plásticos en entornos marinos. La tendencia observada parece relacionarse con la disponibilidad de imágenes satelitales de mayor resolución, el acceso a datos observacionales más frecuentes y el desarrollo de arquitecturas neuronales aplicadas a problemas ambientales complejos (26-28).

En el dominio específico de la detección de residuos plásticos marinos, los estudios publicados antes de 2020 cumplieron un papel relevante al demostrar la viabilidad operativa de los enfoques basados en imágenes. Los trabajos de Kylili et al. y Fallati et al. mostraron que los modelos convolucionales y las imágenes obtenidas mediante vehículos aéreos no tripulados podían emplearse para identificar y cuantificar residuos plásticos flotantes o costeros (11,29).

La expansión posterior parece asociarse con la disponibilidad de conjuntos de datos estructurados y marcos de evaluación comparativa. En este contexto, el conjunto MARIDA desarrollado por Kikaki et al. proporcionó una referencia multispectral basada en imágenes Sentinel-2, lo que permitió evaluar algoritmos de aprendizaje automático bajo condiciones más comparables (30). Por tanto, la evolución temporal observada puede interpretarse como un desplazamiento desde aplicaciones exploratorias hacia enfoques más especializados; sin embargo, la madurez metodológica del campo aún depende de avances adicionales en estandarización de datos, validación externa y comparabilidad entre modelos (31,32).

La concentración de publicaciones en un grupo limitado de revistas de alto impacto sugiere que la investigación sobre aprendizaje automático aplicado a la detección de plásticos marinos se ha insertado progresivamente en canales editoriales consolidados. Revistas como *Marine Pollution Bulletin*, *Science of the Total Environment* y *Remote Sensing* funcionan como espacios centrales de difusión, debido a su vinculación con ciencias ambientales, contaminación marina, teledetección y observación de la Tierra. Esta

concentración editorial no implica necesariamente homogeneidad metodológica, pero sí muestra que el tema ha ganado presencia en revistas especializadas en problemas ambientales y tecnologías de monitoreo.

Este patrón coincide con análisis bibliométricos previos que identifican estas revistas como nodos relevantes en la investigación sobre contaminación marina y residuos plásticos, especialmente cuando se integran tecnologías de detección, procesamiento de imágenes y modelos computacionales avanzados ^(33,34). De forma similar, estudios bibliométricos sobre microplásticos han señalado a *Marine Pollution Bulletin* y *Science of the Total Environment* como fuentes recurrentes y altamente productivas dentro del campo de la contaminación plástica ^(35,36). La presencia de revistas especializadas en observación terrestre, teledetección e ingeniería indica que el campo se ubica en la intersección entre ciencias ambientales, visión por computadora y análisis de datos espaciales. Revisiones recientes destacan que las imágenes satelitales, aéreas y multispectrales constituyen una base metodológica importante para detectar, segmentar y localizar residuos plásticos en ambientes acuáticos y terrestres ^(27,32). Por ello, la estructura editorial observada refleja la naturaleza interdisciplinaria del campo.

Asimismo, la presencia de revistas vinculadas con IEEE muestra que una parte de la producción se orienta hacia soluciones tecnológicas aplicadas, especialmente en detección de objetos, clasificación automática y procesamiento de imágenes. Esta convergencia entre ingeniería, ciencias de la computación y monitoreo ambiental fortalece el potencial aplicado del campo, aunque también exige mayor claridad en la comparación de métricas, tipos de sensores y condiciones de evaluación ^(37,38).

Los resultados muestran que la producción científica se concentra en un conjunto reducido de autores, con un máximo de cuatro publicaciones por investigador dentro del corpus analizado. Los autores más productivos se encuentran afiliados a instituciones vinculadas con ingeniería, ciencias marinas, teledetección e investigación aplicada, lo que respalda la interpretación de un campo interdisciplinario. El impacto de citación se concentra en estudios que introdujeron metodologías operativas, marcos de detección o conjuntos de datos reutilizables. En particular, los trabajos de Martin et al. mostraron que la integración de imágenes obtenidas por vehículos aéreos no tripulados con modelos supervisados podía ampliar la cobertura espacial del monitoreo costero frente a los métodos manuales tradicionales ^(39,40). De manera similar, los estudios de Fallati et al. y Gonçalves et al. contribuyeron a consolidar el uso de plataformas aéreas no tripuladas y modelos de clasificación automatizada para cuantificar residuos marinos en ambientes costeros ^(29,41).

En una escala analítica diferente, Meyers et al. extendieron las aplicaciones del aprendizaje automático hacia la identificación de microplásticos mediante procedimientos semiautomatizados basados en análisis de imágenes fluorescentes ⁽⁴²⁾. Esto muestra que el campo también incorpora aproximaciones de laboratorio orientadas a mejorar la eficiencia y reproducibilidad en la identificación de partículas plásticas.

El desarrollo de infraestructuras de datos de referencia, como MARIDA, constituye un componente relevante para la evolución del campo. La disponibilidad de conjuntos de datos comparables permite validar modelos bajo criterios más consistentes, facilita el contraste entre arquitecturas y mejora la reproducibilidad metodológica ⁽³⁰⁾. No obstante, la dependencia de pocos conjuntos de datos de referencia también puede limitar la generalización de los modelos si estos no incorporan suficiente diversidad geográfica, oceanográfica y ambiental.

La configuración geográfica de la producción científica evidencia una mayor representación de Asia oriental y Europa occidental, con liderazgo de China y contribuciones importantes de países como la República de Corea, India, Portugal, Grecia, Italia, España y Bélgica. Este patrón debe interpretarse como una concentración de afiliaciones científicas y no necesariamente como una medida directa de capacidad tecnológica nacional o impacto ambiental del problema. Sin embargo, la mayor presencia de estos países sugiere que el desarrollo de aplicaciones de aprendizaje automático para la detección de plásticos marinos

se articula principalmente en regiones con infraestructura científica, capacidad computacional y acceso a plataformas de observación ambiental (33,36,43).

En el caso de la detección automatizada basada en imágenes, esta concentración puede estar relacionada con la disponibilidad de programas de observación terrestre, plataformas satelitales de acceso abierto, capacidades institucionales para generar datos de entrenamiento y experiencia previa en teledetección ambiental. La validación comparativa de modelos de aprendizaje profundo requiere datos multispectrales consistentes, escenarios de prueba documentados y protocolos de evaluación suficientemente claros (30,32). Estas condiciones no están distribuidas de manera homogénea a escala global, lo que puede explicar parte de la concentración observada en determinados países y regiones.

La menor representación de América Latina, África y algunas regiones de Medio Oriente constituye una limitación relevante para la diversidad ambiental del campo. Las condiciones oceanográficas, climáticas, costeras y socioambientales varían ampliamente entre regiones, por lo que los modelos entrenados en contextos limitados pueden presentar problemas de transferencia cuando se aplican a escenarios diferentes. En consecuencia, la baja participación de regiones subrepresentadas refleja una brecha de producción científica y un posible riesgo para la generalización de los modelos de detección automatizada en contextos marinos diversos (34,36).

La estructura temática del campo se organiza alrededor de un eje metodológico dominante: el uso del aprendizaje automático aplicado a la detección de contaminación plástica en ambientes marinos. La recurrencia de términos como machine learning, deep learning, object detection y convolutional neural network indica que una parte importante de la agenda reciente se sostiene en técnicas de visión por computadora y en tareas de detección, clasificación y segmentación basadas en imágenes. Esta orientación es coherente con revisiones que describen a los modelos convolucionales como uno de los enfoques más utilizados para localizar residuos plásticos en datos visuales de distinta escala, desde imágenes obtenidas por UAV hasta registros satelitales (11,31).

La red de coocurrencia muestra dos clústeres principales conectados, lo que permite interpretar la organización interna del campo. El primer clúster agrupa términos como machine learning, plastic waste y waste, asociados con el desarrollo de enfoques computacionales y con la formulación del problema desde una perspectiva metodológica y de análisis de datos. El segundo clúster concentra términos como marine pollution, marine debris, deep learning y remote sensing, vinculados con el contexto ambiental marino, las plataformas de observación y las aplicaciones de monitoreo. La conexión entre ambos clústeres sugiere que el campo avanza por la integración entre capacidades algorítmicas y fuentes observacionales, más que por el desarrollo aislado de líneas temáticas independientes.

La evolución temática refuerza esta lectura. Durante el periodo 2018–2021, el término marine debris aparece como eje articulador, asociado con una etapa inicial de identificación de residuos marinos y con fuentes de datos como aerial photograph. En el periodo 2022–2025 se observa una reorganización hacia deep learning, junto con una diferenciación más explícita hacia plastic y microplastics. Este cambio sugiere una especialización progresiva del objeto de estudio y de las tareas de detección, en la cual el campo pasa de enfoques generales de identificación de residuos marinos hacia aproximaciones más específicas basadas en modelos avanzados y datos visuales de mayor complejidad.

No obstante, esta transición también introduce desafíos metodológicos. La detección de macroplásticos mediante imágenes satelitales o aéreas implica problemas distintos a la identificación de microplásticos en laboratorio o en muestras ambientales. Factores como iluminación, resolución espacial, turbidez, oleaje, color del fondo, similitud entre objetos y disponibilidad de datos anotados pueden afectar el rendimiento de los modelos. Por tanto, aunque la evolución temática evidencia un desplazamiento hacia enfoques más

especializados, la comparabilidad entre estudios sigue siendo limitada cuando las tareas, sensores, métricas y escenarios de validación no son equivalentes ⁽³²⁾.

Las redes de colaboración muestran una estructura fragmentada, con clústeres pequeños y escasa interconexión entre grupos, tanto en la red de coautoría como en la colaboración entre países. Este patrón suele observarse en líneas interdisciplinarias donde convergen ciencias ambientales y aprendizaje automático, debido a que el avance depende de capacidades específicas como acceso a datos, infraestructura de cómputo y experiencia técnica, factores que tienden a concentrarse en determinados equipos e instituciones ^(22,23).

En la red de autores se observa que la colaboración ocurre principalmente dentro de equipos relativamente cerrados, con vínculos densos al interior y pocos puentes entre clústeres. La presencia de diádas y grupos pequeños sugiere que muchas contribuciones se producen como desarrollos situados, ligados a un tipo de dato o plataforma concreta, como UAV o imágenes satelitales. Esta configuración puede favorecer la especialización técnica, pero también puede limitar la circulación de metodologías, datos y criterios de evaluación entre grupos que trabajan con condiciones ambientales distintas o con fuentes de datos diferentes. Este rasgo es consistente con revisiones que subrayan la dependencia de plataformas de observación en aplicaciones de deep learning para el monitoreo de residuos ⁽²⁷⁾.

A nivel internacional, la red de países concentra los vínculos en un conjunto reducido de naciones con alta producción, con conexiones más visibles en Asia oriental, América del Norte y Europa. Este patrón sugiere una concentración regional de capacidades científicas y colaborativas, aunque no permite afirmar por sí solo una desigualdad estructural en sentido causal. La baja presencia de regiones subrepresentadas y su conexión periférica puede reducir la diversidad de escenarios usados para entrenar y validar modelos, lo que podría influir en la generalización y aplicabilidad de las soluciones propuestas en contextos marinos distintos ^(34,43).

Como implicancia, la fragmentación colaborativa puede dificultar la estandarización de metodologías, la comparación entre estudios y la construcción de benchmarks más representativos. Incrementar la cooperación intergrupar, compartir conjuntos de datos y armonizar protocolos de evaluación aparece como una condición práctica para que el campo avance desde desarrollos locales exitosos hacia soluciones con mayor transferibilidad geográfica y ambiental.

El presente estudio presenta limitaciones inherentes a su diseño bibliométrico. En primer lugar, el análisis se restringió a documentos indexados en Scopus y a una estrategia de búsqueda basada en términos operativos específicos. Por ello, podrían haberse excluido estudios relevantes publicados en otras bases de datos, en literatura gris, en actas técnicas o bajo denominaciones alternativas no capturadas por la ecuación de búsqueda. En segundo lugar, los indicadores de citación, coautoría y coocurrencia permiten identificar patrones estructurales de producción científica, pero no sustituyen una evaluación cualitativa del rigor metodológico ni del desempeño empírico individual de los estudios reportados.

Futuras investigaciones bibliométricas podrían ampliar el análisis mediante la comparación entre bases de datos como Scopus, Web of Science y Dimensions, con el fin de evaluar posibles diferencias en cobertura documental, visibilidad de autores, distribución geográfica y redes de colaboración. También sería pertinente desarrollar análisis longitudinales más detallados sobre la evolución temática del campo, así como estudios de cocitación, acoplamiento bibliográfico y evolución de palabras clave para identificar con mayor precisión los frentes emergentes de investigación. Estas aproximaciones permitirían fortalecer la comprensión de la estructura intelectual del campo y de sus dinámicas de desarrollo científico.

Conclusiones

El aprendizaje automático aplicado a la detección de contaminación plástica en entornos marinos muestra una expansión científica sostenida desde 2020 y una orientación temática cada vez más especializada. La producción analizada evidencia el predominio de enfoques basados en aprendizaje profundo, detección de objetos, redes neuronales convolucionales, visión por computadora y teledetección. Este desplazamiento muestra que el campo ha avanzado desde aplicaciones iniciales de identificación de residuos marinos hacia estrategias automatizadas de detección, clasificación y monitoreo, apoyadas en imágenes satelitales, aéreas, submarinas y conjuntos de datos reutilizables.

La estructura científica del campo se concentra en revistas de alta visibilidad, autores e instituciones especializadas y documentos con fuerte impacto de citación, aunque las redes de colaboración todavía presentan fragmentación entre grupos y regiones. La menor participación de América Latina, África y otras regiones menos representadas puede limitar la diversidad de escenarios ambientales considerados en el entrenamiento y validación de modelos. El avance del campo requiere ampliar bases de datos abiertas, fortalecer protocolos comparables de evaluación, validar los modelos en contextos marinos diversos y promover cooperación científica interregional para desarrollar sistemas de detección automatizada más robustos, reproducibles y aplicables al monitoreo ambiental global.

Acerca de

Financiamiento: Los autores declaran que no recibieron financiamiento para esta investigación.

Conflicto de interés: Los autores declaran no tener conflicto de intereses.

Certificación ética: El protocolo del presente estudio fue sometido a revisión y aprobado por el Comité de Ética en Investigación de la Universidad, en cumplimiento de los principios éticos y normativas institucionales aplicables.

Historia del artículo: Artículo recibido 27 de marzo 2026 | Aceptado 15 de mayo 2026 | Publicado 19 de junio 2026

Referencias

1. Li WC, Tse HF, Leung HM, Yue YK. Degradation of plastic waste in the marine environment. In: Shahnawaz M, Sangale MK, Daochen Z, Ade AB, editors. Impact of plastic waste on the marine biota. Singapore: Springer; 2022. 143-174. <https://doi.org/10.1007/978-981-16-5403-98>
2. Borrelle SB, Ringma J, Law KL, Monnahan CC, Lebreton L, McGivern A, et al. Predicted growth in plastic waste exceeds efforts to mitigate plastic pollution. *Science*. 2020;369(6509):1515-1518. <https://doi.org/10.1126/science.aba3656>
3. Fulke AB, Bhanushali S, Jadhav HS. Global marine plastic pollution: sources, distribution, implications on human health and mitigation strategies. *Continental Shelf Research*. 2026;296:105578. <https://doi.org/10.1016/j.csr.2025.105578>
4. Singh B, Kaunert C, Gautam R, Ravesangar K, Jermittiparsert K. Escalating legal framework for water governance and eliminating plastic pollution in alignment with SDG 14 (life below water). In: Community resilience and climate change challenges: pursuit of Sustainable Development Goals (SDGs). Hershey: IGI Global; 2024. p. 249-270. <https://doi.org/10.4018/979-8-3693-6522-9.ch013>

5. Gacutan J, Oliver JL, Tait H, Praphotjanaporn T, Milligan BM. Exploring how citizen science projects measuring beach plastic debris can support UN Sustainable Development Goals. *Citizen Science: Theory and Practice*. 2023;8(1):563. <https://doi.org/10.5334/cstp.563>
6. Drogkoula M, Kokkinos K, Samaras N. A comprehensive survey of machine learning methodologies with emphasis in water resources management. *Applied Sciences*. 2023;13(22):12147. <https://doi.org/10.3390/app132212147>
7. Sheik AG, Kumar A, Patnaik R, Kumari S, Bux F. Machine learning-based design and monitoring of algae blooms: recent trends and future perspectives: a short review. *Critical Reviews in Environmental Science and Technology*. 2024;54(7):509-532. <https://doi.org/10.1080/10643389.2023.2252313>
8. Kannankai MP, Babu AJ, Radhakrishnan A, Alex RK, Borah A, Devipriya SP. Machine learning aided meta-analysis of microplastic polymer composition in global marine environment. *Journal of Hazardous Materials*. 2022;440:129801. <https://doi.org/10.1016/j.jhazmat.2022.129801>
9. Edeh MO, Dalal S, Alhussein M, Aurangzeb K, Seth B, Kumar K. A novel deep learning model for predicting marine pollution for sustainable ocean management. *PeerJ Computer Science*. 2024;10:e2482. <https://doi.org/10.7717/peerj-cs.2482>
10. Cortesi I, Masiero A, De Giglio M, Tucci G, Dubbini M. Random forest-based river plastic detection with a handheld multispectral camera. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. 2021;XLIII-B1-2021:9-14. <https://doi.org/10.5194/isprs-archives-XLIII-B1-2021-9-2021>
11. Kyliki K, Kyriakides I, Artusi A, Hadjistassou C. Identifying floating plastic marine debris using a deep learning approach. *Environmental Science and Pollution Research*. 2019;26(17):17091-17099. <https://doi.org/10.1007/s11356-019-05148-4>
12. Djafar I, Syarif S. Development of a deep learning hybrid model for classification of plastic waste objects in the coastal environment. In: *Proceedings of the 2025 International Conference on Advancement in Data Science, E-learning and Information System*; 2025. p. 1-6. <https://doi.org/10.1109/ICADEIS65852.2025.10933237>
13. Yang X, Chen Y, Zhou Y, Tong F. A three-dimensional marine plastic litter real-time detection embedded system based on deep learning. *Marine Pollution Bulletin*. 2025;213:117603. <https://doi.org/10.1016/j.marpolbul.2025.117603>
14. Watanabe JI, Shao Y, Miura N. Underwater and airborne monitoring of marine ecosystems and debris. *Journal of Applied Remote Sensing*. 2019;13(4):044509. <https://doi.org/10.1117/1.JRS.13.044509>
15. Hipolito JC, Sarraga Alon A, Amorado RV, Fernando MGZ, De Chavez PIC. Detection of underwater marine plastic debris using an augmented low sample size dataset for machine vision system: a deep transfer learning approach. In: *Proceedings of the 19th IEEE Student Conference on Research and Development*; 2021. p. 82-86. <https://doi.org/10.1109/SCORED53546.2021.9652703>
16. Adeoba MI, Pandelani T, Ngwangwa H, Masebe T. The role of artificial intelligence in sustainable ocean waste tracking and management: a bibliometric analysis. *Sustainability*. 2025;17(9):3912. <https://doi.org/10.3390/su17093912>
17. Alloghani MA. Using AI to monitor marine environmental pollution: systematic review. In: *Artificial intelligence and sustainability*. Cham: Springer; 2024. p. 87-97. https://doi.org/10.1007/978-3-031-45214-7_5
18. Perera IJJUN, Sandaruwan RDC, Bellanthudawa BKA. Coastal and marine plastic pollution monitoring and control using remote sensing (RS) and artificial intelligence (AI) technologies. In: *Coastal and marine pollution: source to sink, mitigation and management*. Hoboken: Wiley; 2025. p. 329-345. <https://doi.org/10.1002/9781394237029.ch17>

19. Elouidani R, Outouzzalt A. Artificial intelligence for a sustainable finance: a bibliometric analysis. In: International Conference on Advanced Intelligent Systems for Sustainable Development. Lecture Notes in Networks and Systems. Cham: Springer; 2023. https://doi.org/10.1007/978-3-031-26384-2_46
20. Ankrah J, Monteiro A, Madureira H. Bibliometric analysis of data sources and tools for shoreline change analysis and detection. Sustainability. 2022;14(9):4895. <https://doi.org/10.3390/su14094895>
21. Liu Y, Nor RM, Ishak MK, Li X. How does environmental regulation matter? An analysis of the current research hotspots and future direction. Journal of Infrastructure, Policy and Development. 2024;8(8):5387. <https://doi.org/10.24294/jipd.v8i8.5387>
22. Zupic I, Čater T. Bibliometric methods in management and organization. Organizational Research Methods. 2015;18(3):429-472. <https://doi.org/10.1177/1094428114562629>
23. Donthu N, Kumar S, Mukherjee D, Pandey N, Lim WM. How to conduct a bibliometric analysis: an overview and guidelines. Journal of Business Research. 2021;133:285-296. <https://doi.org/10.1016/j.jbusres.2021.04.070>
24. Page MJ, McKenzie JE, Bossuyt PM, Boutron I, Hoffmann TC, Mulrow CD, et al. Declaración PRISMA 2020: una guía actualizada para la publicación de revisiones sistemáticas. Revista Española de Cardiología. 2021;74(9):790-799. <https://doi.org/10.1016/j.recesp.2021.06.016>
25. Aria M, Cuccurullo C. bibliometrix: an R-tool for comprehensive science mapping analysis. Journal of Informetrics. 2017;11(4):959-975. <https://doi.org/10.1016/j.joi.2017.08.007>
26. Khriiss A, Elmiad AK, Badaoui M, Barkaoui A, Zarhloule Y. Advances in machine learning and deep learning approaches for plastic litter detection in marine environments. Journal of Theoretical and Applied Information Technology. 2024;102(5):1885-1895. <https://doi.org/10.5281/zenodo.18609507>
27. Wang B, Xing Y, Wang N, Chen CLP. Monitoring waste from uncrewed aerial vehicles and satellite imagery using deep learning techniques: a review. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. 2024;17:20064-20079. <https://doi.org/10.1109/JSTARS.2024.3488056>
28. Yuan Q, Shen H, Li T, Li Z, Li S, Jiang Y, et al. Deep learning in environmental remote sensing: achievements and challenges. Remote Sensing of Environment. 2020;241:111716. <https://doi.org/10.1016/j.rse.2020.111716>
29. Fallati L, Polidori A, Salvatore C, Saponari L, Savini A, Galli P. Anthropogenic marine debris assessment with unmanned aerial vehicle imagery and deep learning: a case study along the beaches of the Republic of Maldives. Science of The Total Environment. 2019;693:133581. <https://doi.org/10.1016/j.scitotenv.2019.133581>
30. Kikaki K, Kakogeorgiou I, Mikeli P, Raitzos DE, Karantzas K. MARIDA: a benchmark for marine debris detection from Sentinel-2 remote sensing data. PLOS ONE. 2022;17(1):e0262247. <https://doi.org/10.1371/journal.pone.0262247>
31. Astorayme MA, Vázquez-Rowe I, Kahhat R. The use of artificial intelligence algorithms to detect macroplastics in aquatic environments: a critical review. Science of The Total Environment. 2024;945:173843. <https://doi.org/10.1016/j.scitotenv.2024.173843>
32. Chen Z, Si W, Johnson VC, Oke SA, Wang S, Lv X, et al. Remote sensing research on plastics in marine and inland water: development, opportunities and challenge. Journal of Environmental Management. 2025;373:123815. <https://doi.org/10.1016/j.jenvman.2024.123815>
33. Zhou C, Bi R, Su C, Liu W, Wang T. The emerging issue of microplastics in marine environment: a bibliometric analysis from 2004 to 2020. Marine Pollution Bulletin. 2022;179:113712. <https://doi.org/10.1016/j.marpolbul.2022.113712>
34. Anthony D, Siriwardana H, Ashvini S, Pallewatta S, Samarasekara SM, Edirisinghe S, et al. Trends in marine pollution mitigation technologies: scientometric analysis of published literature (1990-2022). Regional Studies in Marine Science. 2023;66:103156. <https://doi.org/10.1016/j.rsma.2023.103156>

35. do Amparo SZS, Carvalho LO, Silva GG, Viana MM. Microplastics as contaminants in the Brazilian environment: an updated review. *Environmental Monitoring and Assessment*. 2023;195(12):1414. <https://doi.org/10.1007/s10661-023-12011-0>
36. Mishra M, Sudarsan D, Santos CAG, da Silva RM, Beja SK, Paul S, et al. Current patterns and trends of microplastic pollution in the marine environment: a bibliometric analysis. *Environmental Science and Pollution Research*. 2024;31(15):22925-22944. <https://doi.org/10.1007/s11356-024-32511-x>
37. Rubbens P, Brodie S, Cordier T, Destro Barcellos D, Devos P, Fernandes-Salvador JA, et al. Machine learning in marine ecology: an overview of techniques and applications. *ICES Journal of Marine Science*. 2023;80(7):1829-1853. <https://doi.org/10.1093/icesjms/fsad100>
38. Danilov A, Serdiukova E. Review of methods for automatic plastic detection in water areas using satellite images and machine learning. *Sensors*. 2024;24(16):5089. <https://doi.org/10.3390/s24165089>
39. Martin C, Parkes S, Zhang Q, Zhang X, McCabe MF, Duarte CM. Use of unmanned aerial vehicles for efficient beach litter monitoring. *Marine Pollution Bulletin*. 2018;131:662-673. <https://doi.org/10.1016/j.marpolbul.2018.04.045>
40. Martin C, Zhang Q, Zhai D, Zhang X, Duarte CM. Enabling a large-scale assessment of litter along Saudi Arabian Red Sea shores by combining drones and machine learning. *Environmental Pollution*. 2021;277:116730. <https://doi.org/10.1016/j.envpol.2021.116730>
41. Gonçalves G, Andriolo U, Pinto L, Bessa F. Mapping marine litter using UAS on a beach-dune system: a multidisciplinary approach. *Science of The Total Environment*. 2020;706:135742. <https://doi.org/10.1016/j.scitotenv.2019.135742>
42. Meyers N, Catarino AI, Declercq AM, Brenan A, Devriese L, Vandegehuchte M, et al. Microplastic detection and identification by Nile red staining: towards a semi-automated, cost- and time-effective technique. *Science of The Total Environment*. 2022;823:153441. <https://doi.org/10.1016/j.scitotenv.2022.153441>
43. Yang J, Hu X, Tan F. The mapping of global plastic pollution research: a bibliometric analysis of the progress and thematic trends. *Sustainability*. 2025;17(5):1859. <https://doi.org/10.3390/su17051859>